

**НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ  
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ  
імені ІГОРЯ СІКОРСЬКОГО»  
Приладобудівний факультет  
Кафедра приладів і систем орієнтації і навігації**

До захисту допущено:

Завідувач кафедри

\_\_\_\_\_ Надія БУРАУ

«\_\_\_» \_\_\_\_\_ 20\_\_ р.

**Дипломна робота**

**на здобуття ступеня бакалавра  
за освітньо-професійною програмою «Комп'ютерно - інтегровані технології та  
системи навігації і керування»**

**спеціальності 151 «Автоматизація та комп'ютерно-інтегровані технології»**

**на тему: «Обробка вихідних сигналів акселерометра за допомогою  
нейронних мереж»**

Виконав :

студент IV курсу, групи ПГ-61

Кобиляшний Олексій Геннадійович

\_\_\_\_\_

Керівник:

Асистент, к.т.н., Рупіч Сергій Сергійович

\_\_\_\_\_

Рецензент:

Доцент, к.т.н., Божко К.М.

\_\_\_\_\_

Засвідчую, що у цій дипломній роботі  
немає запозичень з праць інших авторів  
без відповідних посилань.

Студент \_\_\_\_\_

Київ – 2020 року

## АНОТАЦІЯ

Дипломну роботу виконано на 63 аркушах, вона містить перелік посилань на використані джерела з 32 найменувань. У роботі наведено 25 рисунків та 8 таблиць.

Метою даної дипломної роботи є перевірка доцільності використання нейронних мереж для обробки вихідних сигналів акселерометру.

У дипломній роботі розглядається актуальність задачі розпізнавання типів фізичної активності людини. В якості основного джерела отримання інформації використовується акселерометр.

У роботі наведені теоретичні відомості про акселерометр, його фізичний принцип роботи, а також проведено огляд основних технологій виготовлення.

Описано класичні методи обробки інформації та нейронні мережі як інструмент сучасного аналізу даних. В якості основних моделей для обробки сигналів акселерометрів було використано ймовірнісну нейронну мережу та модель логістичної регресії. Проведено дослідження з використання цих методів щодо визначення типу фізичної активності.

Ключові слова: тип фізичної активності людини, штучна нейронна мережа, ймовірнісна нейронна мережа, логістична регресія, класифікація, кластеризація, акселерометр.

## **SUMMARY**

The thesis is presented in 63 pages. It contains bibliography of 32 references. 25 figure and 8 tables are given in the thesis.

The goal of the thesis is checking the feasibility of using neural networks to process the output signals of the accelerometer.

The thesis considers the relevance of the problem of recognizing the types of physical activity. An accelerometer is used as the main source of information.

The paper provides theoretical information about the accelerometer, its physical principle of operation, as well as an overview of the main manufacturing technologies.

Classical methods of information processing and neural networks as a tool of modern data analysis are described. A probabilistic neural network and a logistic regression model were used as the main models for processing accelerometer signals. A study on the use of these methods to determine the type of physical activity.

Key words: type of human physical activity, artificial neural network, probabilistic neural network, logistic regression, classification, clustering, accelerometer.

## ЗМІСТ

АНОТАЦІЯ.....	2
SUMMARY.....	3
ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ І СКОРОЧЕНЬ.....	5
ВСТУП.....	6
РОЗДІЛ 1. ОГЛЯД СТАНУ ПРОБЛЕМИ.....	8
1.1 Загальні теоретичні відомості про акселерометр.....	8
1.1.1 П'єзоелектрична технологія виготовлення датчиків.....	11
1.1.2 П'єзореzystивна технологія виготовлення датчиків.....	12
1.1.3 МЕМС технологія виготовлення датчиків.....	13
1.2 Сфери застосування акселерометрів.....	17
1.3 Сучасні методи обробки інформації.....	21
1.3.1 Загальні принципи та підходи щодо обробки інформації.....	21
1.3.2 Загальна характеристика нейронних мереж.....	25
РОЗДІЛ 2 ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ РОЗПІЗНАВАННЯ СИГНАЛІВ АКСЕЛЕРОМЕТРУ.....	31
2.1 Загальні підходи до задачі класифікації.....	31
2.2 Ймовірнісна нейронна мережа.....	32
2.3 Метод логістичної регресії.....	37
2.4 Опис автономної системи розпізнавання та створення навчальної вибірki даних.....	38
2.5 Застосування системи класифікації фізичної активності у цілях підвищення безпеки інформаційних систем.....	42
2.6 Огляд програми та комп'ютерна програма для дослідження.....	43
2.7 Визначення типу активності людини за допомогою моделі ймовірнісної НМ.....	46
2.8 Визначення типу активності людини за допомогою моделі логістичної регресії.....	49
2.9 Визначення точності розпізнавання для різних даних фізичної	

активності .....	52
2.10    Перевірка ефективності розпізнавання навчених моделей.....	55
2.11    Висновки до розділу.....	56
ВИСНОВКИ.....	58
СПИСОК ЛІТЕРАТУРИ.....	60

## ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ І СКОРОЧЕНЬ

ІМ	- інертна маса
ЧЕ	- чутливий елемент
МЕМС	- мікроелектромеханічні системи
НМ	- нейронна мережа
ІНМ	- штучна нейронна мережа
FAR	- false accept rate
FRR	- false rejection rate

## ВСТУП

Розпізнавання людської активності - це важлива, сучасна сфера, що активно розвивається. Вона виникла як необхідність для багатьох інших мультимедійних, біоінженерних систем. Велика кількість розробок для визначення та класифікація щоденної активності у широкому розумінні використовується під час догляду за здоров'ям та фізичним станом людини, взаємодії людини-машини та при проектуванні людських рухів. Наприклад, проаналізувавши, фізичну активність людини протягом дня можна зробити багато висновків, які приведуть до покращення її життєдіяльності. Також такий аналіз є важливим елементом різноманітних “смарт” систем, або визначним фактором для створення контролерів, що базуються на розпізнаванні певних рухів й виконанні відповідних дій. Технологія розпізнавання рухів може стати важливим елементом різноманітних систем розширивши, або створивши принципово новий функціонал.

В останні роки, було розроблено багато подібних систем для класифікації фізичної активності з використанням мікродатчиків. Щоб зробити можливим використання таких систем у повсякденному житті вони повинні забезпечувати певний перелік необхідних для цього умов. А саме, система датчиків повинна легко одягатися та носитися, а також конструкція має бути позбавлена великої кількості дротів. Оскільки, вона буде сковувати рухи випробовуваного [1].

Не дивлячись на те, що перші системи розпізнавання базувалися на аналізі відео та аудіо вибірок великої кількості даних, від такої технології швидко відійшли у силу низької продуктивності. Від таких низько ефективних методів швидко відмовились на користь систем з використанням сенсорів для визначення прискорення, акселерометрів. Ці датчики мають великий набір переваг, що дуже добре підходять для створення систем розпізнавання активності, а саме: компактні розміри, низька потреба у живленні, низькі ціни, стресостійкість та можливість швидко передавати вихідні дані для подальшої обробки [1].

Одним з важливих елементів різноманітних систем автоматичного

контролю та регулювання є сенсор – вимірювальний пристрій, що визначає та перетворює вимірювальний параметр у сигнал, зручний для зберігання, передачі та обробки. Наявність численних технологічних процесів у таких системах, а також їх функціональна складність, призводять до необхідності широкого вибору датчиків, які фіксують різні фізичні процеси [2]. Приклад таких сенсорів:

- інклінометр, що використовуються для визначення кута нахилу об'єкта;
- акселерометр, що використовуються для вимірювання прискорення об'єкту, або початок його руху;
- манометр, що використовують для контролю за тиском;
- термопара, для контролю за температурою, та багато інших.

Для задачі розпізнавання діяльності та рухів часто використовують сенсор акселерометр, як самостійний датчик, так і елемент складної системи. Акселерометр це пристрій для визначення прискорення, був винайдений ще в кінці 19го сторіччя. Перші тяжкі та громіздкі акселерометри встановлювалися в автомобілі, паровози та пароплави для контролю за швидкістю. Оскільки перші датчики були масивні й складали суттєву частину маси навіть у автомобілях, для того, щоб зробити можливим більш широке застосування датчиків, необхідне було зменшення розмірів та маси. Це значною мірою вплинуло на розвиток технології розробки датчиків.



## РОЗДІЛ 1

### ОГЛЯД СТАНУ ПРОБЛЕМИ

#### 1.1. Загальні теоретичні відомості про акселерометр

Завдяки розвитку мікроелектроніки та обчислювальних потужностей різноманіття використання сенсорів стало надзвичайно широким. Разом із звичним вимірюванням прискорення, що досі є актуальною задачею у системах навігацій літаків, кораблів, підводних суден та ракет, протягом останніх років стрімко розвивається використання акселерометрів для розпізнавання діяльності людини.

Акселерометри реагують на прискорення, що виникає в наслідок дії зовнішніх сил на чутливий елемент сенсору, та визначають його величину. Прискорення - це векторна фізична величина, що дорівнює зміні швидкості тіла за одиницю часу. Якщо прискорення дорівнює нулю, тобто об'єкт спостереження нерухомий, це означає, що дія усіх сил на нього скомпенсована. Прискорення статичне чи динамічне виникає внаслідок дії сили, наприклад, сили гравітації чи механічної. Тому, акселерометри можуть застосовуватися для виміру сили, прискорення, вібрації, руху, переміщення та куту нахилу (тобто положення у просторі). В промисловості виготовляється багато різновидів датчиків, які мають різні принципи дії, діапазони виміру прискорення, масу, габарити та ціни.

Акселерометри складаються з інерційної маси (ІМ), яка, за допомогою пружинних елементів підвісу, змонтована в корпусі (рис. 1.1). Реалізація вихідного сигналу і принципу вимірювання забезпечується перетворювачами переміщень, деформацій, сил (рис. 1.2) і електронікою. Конструктивний вузол, що включає в себе ІМ і підвіс з елементами кріплення, можна визначити як чутливий елемент (ЧЕ) акселерометра [3].




Рис. 1.1. Ілюстрація фізичної моделі акселерометра: а – конструкція фізичної моделі: 1-нерухомий корпус 2 – пружина, закріплена у корпусі; 3 – маса підвішена на пружині; - інерційна маса




Рис. 1.2. Сили, що діють в фізичній моделі акселерометру

По виду переміщень ІМ акселерометри діляться на осьові і маятникові. В осьових акселерометрах конструкція пружинного підвісу забезпечує прямолінійний рух ІМ, а в маятникових – кутовий. Маятникові акселерометри називають також кутовими, а іноді – балковими.

Так як ЧЕ акселерометра знаходиться в полі сил тяжіння, він може вимірювати кути нахилу підстави (об'єкта), на якому закріплений. Акселерометри, що призначенні для вимірювання кутів нахилу, називають нахиломіри.

У акселерометра виділяють вісь чутливості і поперечні осі, які перпендикулярні до неї. Вісь чутливості - це вісь, в напрямку якої можливе

переміщення ІМ, обумовлене конструкцією підвісу. Акселерометри, з однією віссю чутливості, називають однокомпонентними. В одному корпусі можуть бути встановлені ЧЕ з різним направленням осей чутливості (дво- і трикомпонентні акселерометри).

За способом підвісу чутливого елемента відносно корпусу приладу є багато конструктивних рішень, наприклад, акселерометри з механічним підвісом чутливого елемента на жорсткій опорі (на підшипниках, призмах, роликах тощо); з гнучким підвісом (на торсіонах); з гідростатичним або гідродинамічним підвісом чутливого елемента (поплавкові). Можливі також магнітні, електростатичні, кріогенні, а також комбіновані підвіси. В інерціальних системах, зазвичай, застосовують прецизійні поплавкові осьові та маятникові акселерометри з «електричною пружиною» компенсаційного типу [3].

Основними характеристиками акселерометрів є чутливість, діапазон вимірювань, смуга пропускання частот (по рівню 3 дБ), масштабний коефіцієнт, точність, швидкодію тощо.

Вихідний сигнал акселерометра включає інформацію про силу взаємодії чутливого елемента акселерометра і його корпусу в напрямку відповідної осі - осі чутливості приладу.

Важливу роль у питаннях якості, надійності та сфери застосування акселерометрів має технологія виготовлення ЧЕ та особливості конструкції датчику. На сьогодні у світі існує три основних технології виготовлення ЧЕ датчиків прискорення [3]:

- п'єзоелектрична;
- п'єзорезистивна;
- мікроелектромеханічна (MEMS) .

Кожна з технологій має свої переваги та недоліки, які, зазвичай, визначають область застосування датчиків цього типу.

### 1.1.1. П'єзоелектрична технологія виготовлення датчиків

Конструкція п'єзоелектричного акселерометра заснована на використанні п'єзокристала. Кристал встановлюється на велику основу, а зверху на нього монтується інертна маса, яка забезпечує деформацію кристала при виникненні прискорення (рис.1.3) [4].

Деформація кристалу приводить до виникнення різниці електричних потенціалів на його границях, що є перпендикулярними до вісі деформації. На цьому ефекті й базується принцип виміру прискорення – електричний сигнал, що знімається з кристалу, створюється прискоренням і є йому пропорційним. При цьому, чутливість датчику визначається п'єзоелектричним коефіцієнтом кристалу, тобто на пряму залежить від матеріалу.



Рис. 1.3. Схема принципу роботи п'єзоелектричного акселерометру

Використання кристалу в якості чутливого елементу та практично відсутність рухомих елементів, робить датчики цього типу дуже стійкими до зовнішньої дії, в тому числі до ударів високої амплітуди (до 6000g), а також дії високих температур (до 350 °C). Специфіка чутливого елементу надає можливість проводити вимірювання в широкому діапазоні частот, що важливо для динамічних задач. Ще однією суттєвою перевагою датчиків такого типу є компактні розміри.

Проте, п'єзоелектричні акселерометри, незважаючи на свою зручність, мають й ряд недоліків, що виникають із особливостей конструкції датчику, та

його матеріалів. Першим суттєвим недоліком є необхідність використання електричних з'єднань з високим опором для підключення датчику к іншим елементам системи. Другим недоліком можна назвати низьку стабільність величини при якій датчик визначає вихідний сигнал у стані спокою. Також вихідний сигнал часто залежить від термостабільності, при різкій зміні температури зовнішнього середовища виникає необхідність введення поправки на зміну температури. Ще одним недоліком, що виникає внаслідок використання п'єзокристалу, є їх висока гігроскопічність. Тому зберігання та експлуатація таких датчиків потребує контролю за вологістю навколишнього середовища, або забезпечення повної герметичності датчику.

### **1.1.2. П'єзорезисторна технологія виготовлення датчиків**

В п'єзорезистивних датчиках прискорення (рис. 1.5) для вимірювання використовуються гнучкі дифузійні кремнієві резистори, приєднані до однієї чи кількох кремнієвих консольних балок, що підтримують інерційну масу. Прискорення маси згинає балку і, відповідно, змінює опір резисторів, створюючи розбалансування моста Уїтсона, в схему якого, як правило, включені вимірювачі напруги – (рис.1.4) [5]. Це забезпечує реакцію на статичне прискорення. На рис. 1.4 наведено схему п'єзорезистивного акселерометру, де 1 — кремнієва структура з консольними балками, які підтримують інерційну масу; 2 — підтримуюча основа; 3 — інерційна маса; 4 — згинні кремнієві резистори (strain gages); 5 — електричне з'єднання резисторів (схематичне зображення моста Уїтстона); 6 — термінали мікроелектромеханічні системи (МЕМС) — структури (виходи моста).




Рис. 1.4. Схема п'єзореzystивного акселерометру

Специфіка використання, а також недоліки та переваги дуже схожі з п'єзоелектричними акселерометрами й пов'язані з використанням п'єзоматеріалами, що використовуються в конструкції.

До основних переваг сенсорів, виконаних за такою технологією, можна віднести:

- широкий частотний діапазон вимірювання;
- стійкість до високих прискорень (до 20000g);
- вібраційне та ударне навантаження;
- здатність до функціонування при температурах до 350 °C;
- надійна, жорстка конструкція;
- добре відпрацьована, автоматизована технологія виготовлення також є вагомою перевагою.

До недоліків можна віднести погану термостійкість, чутливість до вологи, відсутність можливості статичних замірів, а також відсутність можливості реалізації самотестування.

### 1.1.3. MEMC технологія виготовлення датчиків

Мікроелектромеханічна система (MEMC) – технології і пристрої, що поєднують в собі мікроелектронні і мікромеханічні компоненти. MEMC-

пристрої, зазвичай, виготовляють на кремнієвій підкладці за допомогою технології мікрообробки, аналогічно технології виготовлення однокристальних інтегральних мікросхем. Типові розміри мікромеханічних елементів лежать в діапазоні від 1 мікрометра до 100 мікрометрів, тоді як розміри кристала MEMC мікросхеми мають розміри від 20 мікрометрів до одного міліметра [6].

MEMC акселерометр (рис. 1.5) складається із кремнієвої рамки 1 і інерційної маси 2. Двома тонкими торсіонами 3, інерційна маса 4 з'єднана з кремнієвою рамкою. Ця маса з'єднується з одного краю кремнієвої рамки механічно, а з іншого краю через пару імплантованих п'єзореzystорів 5, 6, які створюють напівміст. Два напівмосту з'єднуються в мостову схему. При впливі прискорення  $a$ , інерційна маса переміщується, згинаючи торсіони та викликаючи деформацію п'єзореzystорів. Таким чином, датчик і розташована поза кристалом електронна схема обробки сигналів через деформацію п'єзореzystорів, створюють, при впливі прискорення, вихідний сигнал, який надходить до споживачів, зокрема в схему безплатформної інерціальної навігаційної системи (ІНС) [6].




Рис. 1.5. Акселерометр, що виконаний за технологією MEMC

Прикладом сучасного MEMC акселерометра є сенсор від компанії Analog Devices ADXL335 (рис. 1.6).




Рис. 1.6. Акселерометр ADXL335

Сучасні MEMS акселерометри розділяються на два основних типи за технологічними особливостями виготовлення самої MEMS структури, це [8]:

- планарна технологія;
- об'ємна технологія.

Датчики, що виготовленні за планарною технологією (рис. 1.7), мають гребінчасту структуру інертної маси, що здатна коливатися одразу у кількох площинах.




Рис. 1.7. Схематичне зображення планарного акселерометру



Оскільки ІМ може коливатися у кількох напрямках, це дає можливість виконувати вимір прискорення одразу по декільком вісям чутливості. Такі МЕМС акселерометри надійніші, мають менші габарити, якщо порівнювати із п'єзрезистивними та п'єзоелектричними. Це робить їх також дешевшими. Проте, невелика інертна маса та велика величина зазору між електродами викликають ряд недоліків, такі як високий рівень шумів і низька (в порівнянні з датчиками, виконаних за об'ємною технологією) стабільність робочих характеристик.

Датчики, виконані за об'ємною технологією (рис. 1.8) мають інертну масу, вільно підвішену на консолі над площиною основи.




Рис. 1.8. МЕМС акселерометр

Така технологія виготовлення (об'ємне прецизійне травлення і технологія сплавлення кремнію) набагато складніша й потребує більше часу, а також більш складного обладнання для виготовлення. При цьому, габарити більші ніж у акселерометру, виготовленому за планарної технології, а також відсутня можливість реалізації виміру по багатьом вісям у рамках однієї комірки. Проте, такі датчики тихіші і мають високу стабільність вимірювальної характеристики [7].

Сучасне налагоджене масштабне виробництво МЕМС акселерометрів, їх надійність та компактні розміри при невеликій ціні, робить датчик такого типу

ідеальним рішенням для багатьох нових розробок.

Основним недоліком таких акселерометрів, є значна нерівномірність амплітудно-частотної характеристики (АЧХ), внаслідок чого звужується частотний діапазон вимірювання вібрації. Крім того, на відміну від п'єзоакселерометрів, нечутливих до статичних прискорень (наприклад, до дії сили тяжіння), МЕМС датчики вимірюють як динамічні, так і статичні прискорення, а тому, при вимірюванні вібрації, потребують аналогової фільтрації вихідного сигналу [9].

Кожна з трьох, описаних вище технологій виготовлення акселерометрів (п'єзоелектрична, п'єзорезистивна, мікроелектромеханічна), мають свої переваги та недоліки. П'єзоелектричні та п'єзорезисторні акселерометри мають можливість працювати у жорстких умовах експлуатації – при високих температурах, ударних й вібраційних похибках. За допомогою таких сенсорів можна проводити вимір прискорення у широкому діапазоні. МЕМС датчики демонструють високу точність, надійність та стабільність виміру, реагуючи на найменшу зміну вимірювального параметру. Модель акселерометру та технологія його виготовлення повинна обиратися в залежності від умов його експлуатації та системи, для якої датчик використовується [10].

## **1.2. Сфери застосування мікроелектромеханічних акселерометрів**

Технології МЕМС, за якими виконуються сучасні акселерометри, на сьогоднішній день набули такого рівня, що розвивається не тільки їх масове виробництво, а й стрімко росте різноманіття галузей їх застосування. Окрім використання у багатьох видах систем та техніки, протягом останніх років актуальною задачею стало використання акселерометрів у повсякденній діяльності людини.

Широке застосування акселерометри знайшли у наступних сферах:

1. Автомобільна промисловість. Автомобілісти, кожен день сідаючи за кермо, іноді навіть не розуміють, що датчики прискорення є найважливішими

елементами системи безпеки. Акселерометр реєструє аварійні ситуації та запускає розгортання подушок безпеки. Окрім цього, датчики прискорення є складовими систем контролю тиску в шинах (англ. Tire Pressure Monitoring System; TPMS), де вони визначають початок руху, швидкість та напрямлення обертання коліс, а також допомагають економити енергію батареї [11]. У відео реєстраторах за допомогою акселерометру визначаються дії водія, що можуть призвести до виникнення аварійних ситуацій, такі як різке гальмування, набір швидкості та різкі повороти. При таких діях реєстратор записує відео з особливою позначкою та захищає ці файли від випадкового видалення.

2. У смартфонах. Кожен сучасний телефон оснащується акселерометром. Завдяки можливостям датчику визначати положення смартфона, а також його прискорення, гаджет може виконувати функцію шагоміру. Акселерометр робить можливим керування пристроєм жестами, такими як постукування по корпусу смартфона чи його струшування, перевертання екраном донизу. Кожен жест запускає певний сценарій, наприклад зміна музикального треку, прийняття чи відміна виклику, відключення будильника та багато іншого. При використанні електронних мап акселерометр надає можливість візуально демонструвати положення користувача та його переміщення. Використання датчику в різноманітних додатках чи мобільних іграх, може створити унікальне керування за допомогою рухів пристроєм.

3. У фітнес трекерах акселерометри використовуються для відстежування фізичної активності людини, наприклад кількості кроків, швидкості та пройденої відстані. Сучасні моделі можуть навіть розпізнавати яку саме вправу робить користувач, записуючи їх кількість у відповідні додатки та видавати різні рекомендації з техніки виконання.

4. У смарт годинниках акселерометри, відстежуючи характерні вібрації, надають можливість визначати чим зайнятий користувач, та, навіть, які предмети тримає в руках. Також сучасні годинники можуть розпізнавати характерні жести, які робить користувач, наприклад, постукування по кисті руки чи клацання пальцями, і виконувати запрограмовані дії залежно від них.

Деякі годинники за допомогою акселерометра можуть ідентифікувати користувача за його ходою. Профілювання користувача та його фізичної активності за допомогою акселерометра може зробити смарт годинник важливим елементом іншої системи, запускаючи запрограмовані сценарії при настанні певних умов чи розпізнаючи різні види фізичної активності.

5. У контролерах. Використання акселерометрів у сучасних контролерах надзвичайне широке та актуальне. На базі вихідних даних акселерометру можна створити високоточний інноваційний контролер, де важливо фіксувати та аналізувати фізичну активність людини, наприклад, для спортивних ігор. Однак, зазвичай, акселерометри додають до вже існуючих контролерів, щоб розширити його можливості, та, іноді, щоб спростити конструкцію, позбувшись кнопок. Для керування, за принципом, коли контролер реєструє певні дії користувача, такі як повороти у просторі, струшування чи помаху контролером. Потужність сучасних комп'ютерів стимулює розвиток додатків та ігор з повним зануренням у, так звану, віртуальну реальність. Датчики прискорення являються ідеальним рішенням для захоплення та відтворення у грі рухів користувача, при цьому вже існують костюми створені із використанням акселерометрів, що передають абсолютно усі рухи в віртуальну реальність. Точність передачі даних, про рухи за допомогою костюмів з акселерометрами можуть стимулювати навіть переніс сучасного спорту у такий віртуальний формат. Цілком реально перенесений матч з, наприклад, великого тенісу провести у системі віртуальної реальності.

6. Медико-біологічна практика. У сучасних медичних розробках акселерометр використовують в основному для реабілітаційних цілей. Акселерометр закріплюється на талії чи стегнах та реєструє кількість дій і фізичної активності, та зберігає цю інформацію. Так лікуючий доктор та сам пацієнт можуть відстежувати чи достатньо вправ виконуються відповідно до графіку реабілітації. Також датчики можуть бути використанні для контролю за пацієнтом під час сну. Так, спеціальний браслет на базі акселерометру може сповіщати медсестру, про випадки судорожних коливань або тремору, та

записувати найголовніші їх параметри час й протяжність інцидентів, частоту та період коливань, що полегшує не лише догляд за пацієнтом, а також його лікування [12].

7. Технологія захвату рухів(motion caption). Метод захвату рухів полягає у тому, щоб слідкувати за певними точками на тілі людини й передавати їх рух у вигляді комп'ютерного зображення. Цей метод широко застосовується у кіно індустрії для створення колоритних персонажів, без використання великої кількості гриму. Акселерометр у таких системах є допоміжним датчиком збираючи інформацію про переміщення, знімаючи не лише зміну положення актору, а й його нахили на певні кути. У ігровій індустрії також широко застосовується ця технологія для створення гіпер реалістичної графіки з використанням акторів. У випадках коли 3D модель персонажу створюється на комп'ютері, система захвату рухів за допомогою акселерометрів може бути використана для руху моделі як реальної людини. Окрім наведених випадків, реальне застосування технології Motion Caption може бути значно ширшим. Технологія захвату рухів може бути актуальною й для звичайних людей, якщо такі костюми будуть достатньо зручними й недорогими. За допомогою такої технології можна було б виправити погану поставу, вивчити сучасний вид танцю або виробити правильну техніку бігу. У промисловому проектуванні технологія захвату рухів може стати потужним інструментом для тестування ергономіки проекту ще на етапі проектування. В такому випадку відпадає необхідність створення тестового зразку, що може економити досить великі обсяги фінансових ресурсів.

При аналізі сучасного використання MEMS сенсорів можна сказати, що акселерометри найдоцільніше застосовувати для розширення можливостей різноманітних пристроїв та технічних систем. Крім того, акселерометри використовують для створення високоточних контролерів, що реєструють діяльність та характерні жести користувача. Існують також медико-біологічні системи, на базі акселерометра, що стежать за фізичною активністю, чи

початком випадків. Такі системи значно полегшують догляд та лікування пацієнтів.

### **1.3. Сучасні методи обробки інформації**

#### **1.3.1. Загальні принципи та підходи щодо обробки інформації**

Для того, щоб вдало використовувати акселерометр для розпізнавання людської діяльності, його вихідні данні необхідно обробляти. При цьому, відповідно до типу діяльності необхідно вміти застосувати найбільш доцільний метод, та систему обробки інформації.

Обробку інформації (рис. 1.9) можна здійснити, використовуючи комплекси засобів обчислювальної та інформаційної техніки, за допомогою якої раціонально виконуються чотири групи основних операцій: збір і передача інформації в комп'ютер, її обробка за заздалегідь розробленими алгоритмами та програмами, видавання обробленої інформації користувачам, зберігання й пошук інформації [13].



Рис. 1.9. Схематичне зображення задачі обробки інформації

Першим кроком в обробці інформації є її передача від пристрою зняття інформації, до подальшої підсистеми обробки за допомогою засобів обчислювальної техніки. Схематичне зображення процесу передачі інформації зображено на рис. 1.10. Будь-яка система цифрової передачі даних (цифрова система зв'язку) може бути змодельована за допомогою трьох основних компонентів. Такими компонентами є: передавальний пристрій, канал передачі даних (канал зв'язку), приймальний пристрій. Вплив шумів та інших перешкод

деформує сигнал, що негативно впливає на достовірність та інформативність отриманих даних [14].



Рис. 1.10. Схема передачі інформації

Для того, щоб проаналізувати інформацію, класифікувати її та виявляти певні патерни, сигнал необхідно обробити. При наявності певної вибірки даних, її аналізують та виявляють закономірності за певним методом обробки.

На сьогоднішній день існує багато різних методів обробки інформації. Вони відрізняються своїми підходами та принципами щодо аналізу даних, свій клас вирішуваних задач та відповідні області застосування. До найбільш відомих методів відносять такі [15-18]:

- статистичні;
- логічні;
- кластерні;
- факторні.

До класичних та широко використовуваних методів обробки інформації відносять статистичні методи. Статистичні методи обробки інформації базуються на трьох основних принципах. На першому етапі відбувається збір інформації щодо досліджуваного явища, або даних певного фізичного процесу. На другому етапі статистичного аналізу відбувається первина обробка

інформації та її об'єднання у групи. На третьому етапі групи даних аналізують, що надає можливість установити взаємну залежність між різними факторами і технологічними результатами процесу. Основна задача цього етапу полягає у виявленні взаємозв'язків явищ, визначенні закономірностей їх розвитку та здійсненні прогнозних оцінок [15].

До переваг статистичних методів обробки інформації можна віднести відносно невелику складність математичних розрахунків, якщо порівнювати з іншими методами. А недоліком є необхідність великої кількості даних для обробки, при цьому чим більший масив статистичних даних, тим вище точність оцінки.

Логічний метод обробки інформації – це метод, при якому параметри, що аналізуються, приймають лише два види логічних значень – 0 (*false*) та 1 (*true*). Значення *true* може означати факт наявності певного признаку; відповідно, *false* – відсутність признаку. Прикладом застосування цього акселерометру може бути в прийнятті вихідного сигналу датчику певного значення ( $x=a$ ), в перевищенні сигналу певного порогу ( $x>a$ ). Такий метод зручно використовувати для виникнення прискорення, тобто початку руху людини, але неможливо використати для того щоб конкретно класифікувати певні рухи чи діяльність [16].

Кластерний аналіз (англ. *Data clustering*) — задача розбиття заданої вибірки об'єктів (ситуацій) на підмножини, які називаються кластерами, так, щоб кожен кластер складався з схожих об'єктів, а об'єкти різних кластерів істотно відрізнялися [17]. Завдання кластеризації відноситься до статистичної обробки, а також до широкого класу завдань навчання без вчителя. Кластерний аналіз — це не один алгоритм, а загальна задача, для розв'язання якої використовуються різні підходи. Зокрема, алгоритми побудови кластерів можуть суттєво відрізнятись у розумінні того, що відносити в один кластер і як їх ефективно шукати. Серед популярних концепцій кластерів є групи з елементами, які утворюються ґрунтуючись на відстані між ними, на щільності ділянок у просторі даних, інтервалах або на конкретних статистичних



розподілах. Тому кластеризація може бути сформульована як задача багатокритеріальної оптимізації [17]. Відповідний алгоритм кластеризації та вибору параметрів (включаючи такі параметри, як функція відстані, порогове значення щільності або кількість очікуваних кластерів) залежать від конкретного набору даних та мети використання результатів. Кластерний аналіз як такий є не автоматизованим завданням, а ітераційним процесом виявлення знань або інтерактивної багатокритеріальної оптимізації, який містить спроби та невдачі. Часто доводиться змінювати процес опрацювання даних та параметри моделі поки не буде отримано результат з заданими властивостями [17, 18].

В основі факторного аналізу лежить ідея про те, що за складними взаємопов'язаними структурами стоїть значно простіша структура, що відображає найбільш суттєві характеристики явища, яке визначається, а зовнішні ознаки є функціями скритих загальних факторів інших простих структур. Тобто для аналізу певної групи даних, збирають усі фактори, що впливають на групу даних й прогнозують реакцію системи даних залежно від зміни зовнішніх факторів. Прикладом використання цього методу для обробки вихідних даних акселерометра може бути аналіз оптимальної фізичної активності для людини, або прогнозування оптимальних умов експлуатації для техніки [17, 18].

Сучасний найпотужніший й найбільш гнучкий інструмент обробки інформації це нейронні мережі. Штучні нейронні мережі (ШНМ) – це математична модель, що побудована за принципом функціонування справжньої нервової системи людини. Виникли вони у спробах моделювання реальних процесів, що виникають у мозку людей. ШНМ – це складні системи обробки інформації, що базуються на технічних принципах багатьох інших дисциплін, таких як: нейрофізіологія, математика, статистика, фізика, комп'ютерні науки та техніка. Вони застосовуються у дуже різномірних областях, а саме: моделювання, аналіз числових рядів, розпізнавання образів, обробка сигналів, керування, прогнозування та багато інших [19].

### 1.3.2. Загальна характеристика нейронних мереж

В загальному випадку, НМ представляє собою систему, що моделює спосіб обробки мозку певної задачі. Для того, щоб досягти високої продуктивності, НМ використовують множину взаємозв'язків між елементарними процесорами підрахунків – штучними нейронами. Процедура, що використовується у процесі навчання НМ, називається алгоритмом навчання. Інформація поступає у НМ з оточуючого середовища й використовується у процесі навчання. Для накопичення знань використовуються зв'язки між нейронами, що називаються синаптичними вагами. Алгоритм навчання будує в певному порядку синаптичних вагів НМ для забезпечення необхідної структури взаємозв'язків між нейронами [19].

В залежності від функцій, що виконуються у НМ, нейрони можна поділити на три різновиди [24, 25]:

- вхідні нейрони, на які подається сигнал, кодує вхідний сигнал чи образ зовнішньої середовища; вхідний шар мережі зазвичай не виконує ніяких обчислень, а лише розрізняє вхідні сигнали;
- вихідні нейрони, значення яких представляють виходи нейронних мереж; перетворення в них відбуваються за заздалегідь запрограмованими математичними функціями;
- проміжні нейрони – складають основу нейронних мереж, в них виконується основна обробка інформації.

Нейронні мережі можуть виконувати складні й об'ємні задачі при умові, що обраний тип мережі максимально відповідає типу інформації й особливостям задачі, що вирішується.

Штучні нейронні мережі відрізняються своєю архітектурою: структурою зв'язків між нейронами, кількістю шарів, функцією активації нейронів, алгоритмом навчання. З цієї точки зору серед відомих мереж можна виділити статичні та динамічні, одно- та багатошарові мережі. Схема класифікації штучних нейронних мереж подана на рис. 1.11 [19].

Класифікація штучних нейронних мереж можлива за наступними ознаками:

- за налаштуванням вагів (мережі з фіксованими зв'язками: вагові коефіцієнти нейронної мережі вибираються відразу, виходячи з умов завдання; мережі з динамічними зв'язками: для них в процесі навчання відбувається налаштування синаптичних вагів);
- за характером навчання (з вчителем, без вчителя та змішані);
- за кількістю шарів (одношарові складаються з одного шару нейронів, багатошарові – з декількох);
- за типом вхідної інформації (аналогова: вхідна інформація, представлена у формі дійсних чисел; бінарна: вся вхідна інформація в таких мережах представляється у вигляді нулів і одиниць);
- за типом активаційної функції (функція єдиного скачку: рівень виходів 0 або 1, кусочно-лінійна, сигмоїдальна: виходи безперервних значень, гіперболічного тангенсу: виходи мають область значень в інтервалі  $(-1; 1)$ );
- за часом передачі (синхронні: в кожний момент часу свій стан змінює лише один нейрон, асинхронні: стан міняється відразу у цілої групи нейронів, як правило, у всього шару);
- за напрямком зв'язку (зі зворотніми зв'язками: виходи нейронів пов'язані з входами, без зворотніх зв'язків: не пов'язані) [20].

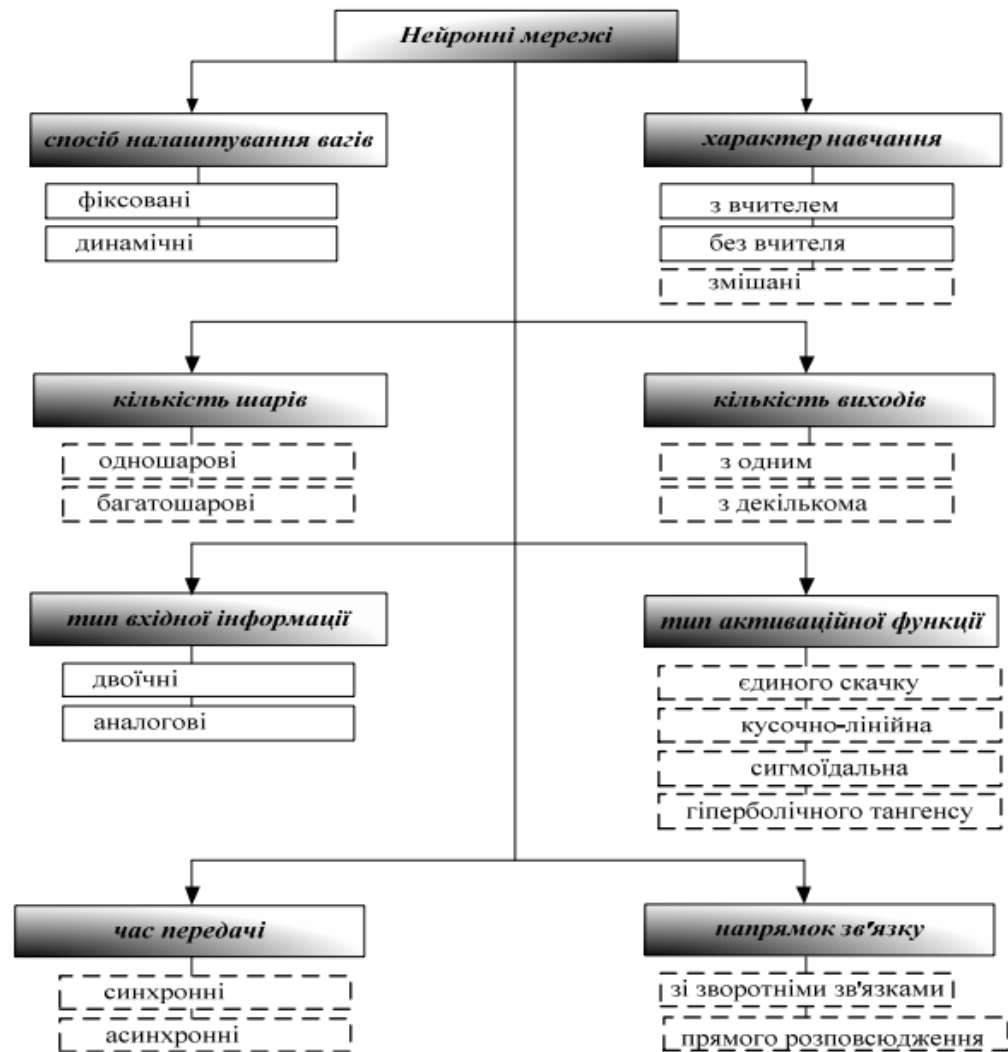


Рис.1.11. Класифікація НМ

Сучасні НМ застосовують для великого переліку різноманітних задач. В том числі, для розпізнавання діяльності людини. Існують мережі, які надзвичайно точно здатні аналізувати дії, що відбуваються на відео. Вчені з Массачусетського технологічного інституту розробили мережу, що розпізнає трансформацію об'єктів на відео у режимі реального часу. Мережа аналізує кадри положення об'єктів на різних етапах відео. Після навчання, технологія здатна розпізнавати один й той же тип активності, шляхом співставлення нових кадрів з вже вивченими видами діяльності. Таким чином, подібна технологія здатна розпізнавати види діяльності. Також, така технологія може прогнозувати, подальші події та розпізнавати певні об'єкти [21].

До основних переваг ШНМ відносяться:

- Аналогія з нейробиологією. ШНМ є технологічною імітацією процесів мозку людини, який є живим доказом того, що відмовостійкість, паралельні розрахунки не тільки можливі, а й є швидким та потужним інструментом вирішення задач. Загалом, майже усі переваги наслідують переваги справжніх нейронних мереж.
- Висока відмовастійкість. Якщо у процесі роботи буде пошкоджено нейрон, або його зв'язки, якість роботи усієї мережі буде знижена, але ШНМ зберігає можливість проводити розрахунки.
- Стійкість до шумів вхідних даних.
- Ефективна адаптивність ШНМ до інших умов. Тобто, НМ, що були навчені працювати у певних умовах навколишнього середовища, мають можливість з легкістю адаптуватися до інших.
- Здатність до обробки нелінійного вхідного сигналу. Штучні нейрони можуть бути лінійними або нелінійними. Нелінійність є важливою властивістю ШНМ, особливо якщо сам фізичний механізм, що відповідає за формування вхідного сигналу, є нелінійним. Наприклад, людська мова, образи або діяльність людини [19].

Не зважаючи на широкий спектр можливостей ШНМ, вони мають набір явних недоліків, а саме:

- для правильного функціонування системи обробки інформації на основі ШНМ необхідно виконувати багатоцикловий процес налаштування внутрішніх елементів та зв'язків між ними;
- при підготовці навчальної вибірки для ШНМ часто виникають проблеми з пошуком достатньої кількості навчальних прикладів;
- навчання ШНМ часто приводить до тупикових ситуацій;
- поведінку ШНМ не завжди можна спрогнозувати, що збільшує ризик застосування ШНМ для керування дорогими технічними об'єктами;
- необхідність досить великого часу на навчання мережі, робить неможливим застосування ШНМ у системах реального часу [22].

Нейронні мережі - це сучасний та потужний інструмент для обробки будь-якої інформації. Вони різноманітні та класифікуються за великою кількістю факторів. Використовувати НМ для розпізнавання діяльності людини можливо, доцільно та актуальне.

У розділі були наведені загальні теоретичні відомості щодо сенсору для визначення прискорення – акселерометру. Розглянуто фізичний принцип дії, а також особливості, недоліки та переваги різних технологій виготовлення датчику. Проаналізовано основні сфери та способи використання мікроелектромеханічних акселерометрів. А також наведені основні класичні методи для обробки інформації, та більш детально класифіковано нейронні мережі.

## РОЗДІЛ 2

### ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ РОЗПІЗНАВАННЯ СИГНАЛІВ АКСЕЛЕРОМЕТРУ

#### 2.1. Опис використаних НМ

Задача ідентифікації та класифікації процесів і систем, або створення математичної моделі за результатами спостережень чи досліджень, є актуальною у різних сферах. Проте, класичні підходи та інструменти для цих задач стають все менш придатними для класифікації складних нелінійних систем [23]. ШНМ є потужним інструментом для обробки інформації та добре підходять для розпізнавання та класифікації майже будь яких видів активності, а також сигналів усіх можливих сенсорів.

Однак, ефективне використання інструменту НМ для розпізнавання та класифікації видів діяльності людини потребує чіткий підбір типу мережі, для того щоб, забезпечити достатній рівень точності [1]. Відзначимо, що задачі класифікації дуже погано алгоритмізуються. В більшості складних практичних задачах навчена нейронна мережа виступає як експерт, що володіє великим досвідом і здатний дати відповідь на важке запитання. Такий підхід особливо ефективний у задачах експертної оцінки з тієї причини, що він сполучає у собі здатність комп'ютера до обробки чисел і здатність мозку до узагальнення і розпізнавання. Крім задач класифікації, нейромережі широко використовуються для пошуку залежностей у даних і кластеризації.

Визначимо основні задачі обробки даних [1]:

- Класифікація – віднесення об'єктів (спостережень, подій, сигналів) на апріорно задані групи, так звані класи, всередині кожної з яких вони передбачаються схожими один на одного, мають приблизно однакові

властивості і ознаки. При цьому рішення отримується на основі аналізу значень атрибутів;

- Кластеризація – групування об'єктів (спостережень, подій, сигналів) на основі даних (властивостей), що описують сутність цих об'єктів, у кластери. Об'єкти всередині кластера повинні бути схожими один на одного і відрізнятися від об'єктів, що ввійшли в інші кластери. Чим більше відмінностей між кластерами, тим точніша кластеризація;

Методи, які використовуються для задач класифікації та кластеризації [32]:

- Наївний байєсівський класифікатор - один з найпростіших з алгоритмів класифікації. Принцип роботи класифікатора полягає в обчислення найбільш ймовірного класу/мітки невідомого вхідного об'єкту, опираючись на набір його ознак;
- Логістична регресія. Встановлення ймовірності залежності безперервних вихідних від вхідних змінних;
- Ймовірнісна нейронна мережа. Метод, схожий на логістичну регресію тим що, визначає певну ймовірну належність вхідних даних до певного класу, але відрізняється своєю архітектурою та принципом функціонування.

Для вирішення задачі розпізнавання видів діяльності людини за даними акселерометра розглянемо ймовірнісну НМ та порівняємо результати з моделлю логістичної регресії.

## **2.2. Ймовірнісна нейронна мережа**

Виходи мережі можна інтерпретувати, як оцінки ймовірності приналежності елемента до визначеного класу. Ймовірнісна мережа учить оцінювати функцію щільності ймовірності, її вихід розглядається як очікуване значення моделі в даній точці простору входів. Це значення зв'язане з щільністю ймовірності загального розподілу вхідних і вихідних даних. Задача оцінки щільності ймовірності відноситься до області байєсівської статистики. Звичайна статистика по заданій моделі показує, яка ймовірність того або



іншого виходу. Байєсівська статистика інтерпретує по іншому: правильність моделі оцінюється по наявним достовірним даним, тобто дає можливість оцінювати щільність ймовірності розподілу параметрів моделі по наявним даним. При рішенні задач класифікації можна оцінити щільність ймовірності для кожного класу, порівняти між собою ймовірності приналежності до різних класів і вибрати модель з параметрами, при яких щільність ймовірності буде більшою. Кластери з поруч розташованих точок, свідчать, що в цьому місці щільність ймовірності велика. Біля спостереження є більша довіра до рівня щільності, а в міру віддалення від нього довіра зменшується і прагне до нуля [1].

Приклад структури імовірнісної НМ для вирішення завдання розпізнавання діяльності зображено на рис. 2.1. Вхідний шар мережі не виконує розрахунків й необхідний для прийому та розділення ознак вхідної дати. Кількість нейронів вхідного шару визначається кількістю ознак вхідного вектору  $x$ . Шар зразків містить по одному нейрону для кожної ознаки вхідного вектору з вибірки для навчання мережі. Тобто, при загальному об'ємі вибірки для навчання, що містить  $L$  зразків, шар зразків має складатись з  $L$  кількості нейронів. Вхідний шар та шар зразків створюють повнозв'язну структуру [1].

Другий шар – це шар конкуренції, що містить кількість нейронів, що дорівнює кількості класів, на які розбиваються вхідні образи. Кожен нейрон шару конкуренції має зв'язки тільки з нейронами шару зразків, які відносяться до відповідного класу. Усі синаптичні ваги зв'язків шару конкуренції в традиційній імовірнісній мережі прирівнюється до одиниць. Розмір області сусідства може змінюватися під час періоду навчання [1].

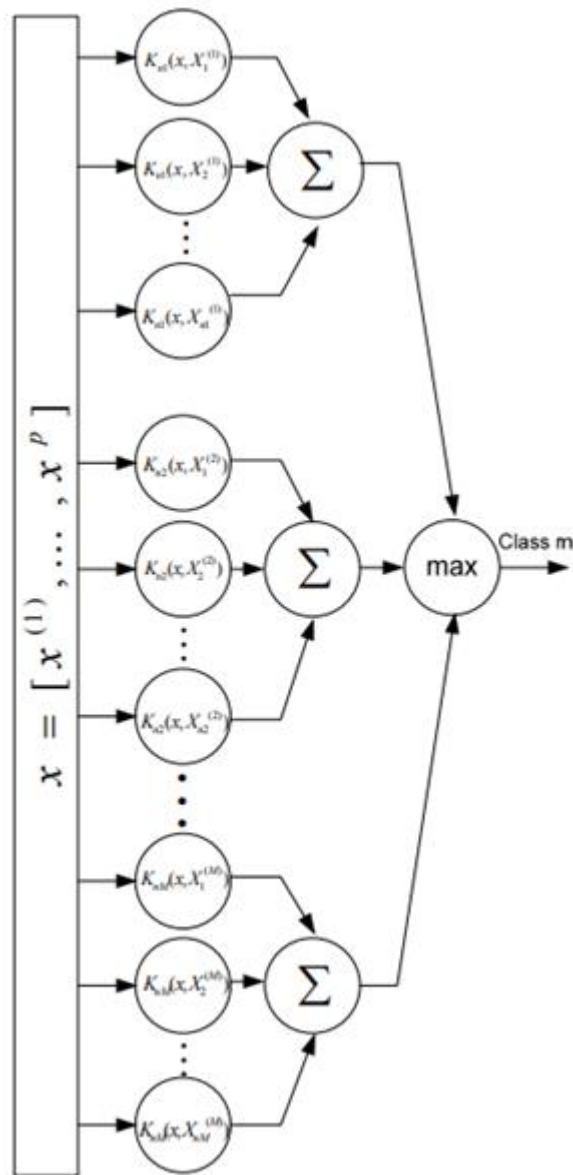


Рис. 2.1 Архітектура ймовірнісної мережі

Вихідний нейрон вказує, який саме нейрон з шару конкуренції має максимальний вхідний сигнал. Тим самим визначається клас, якому належить представлений вхідний образ. Ваги зв'язків нейрону вихідного шару встановлюється так, щоб на його виході ідентифікувався нейрон шару конкуренції з найбільшим значенням активності. Тобто, відбувається навчання методом змагання вихідні нейрони змагаються між собою за активізацію. Подібне навчання має місце в біологічних нейронних мережах. Навчання за допомогою змагання дозволяє кластеризувати вхідні дані: схожі приклади групуються мережею відповідно до кореляції і представляються одним

елементом.

При навчанні модифікуються синаптичні ваги нейрона переможця. Ефект цього правила досягається за рахунок такої зміни збереженого в мережі зразка (вектора синаптичних ваг нейрона-переможця), при якому він стає ближче до вхідного прикладу. Нейрон з найбільшим вихідним сигналом з'являється переможцем і має можливість гальмувати своїх конкурентів і збуджувати сусідів. Використовується вихідний сигнал нейрона-переможця і тільки йому і його сусідам дозволяється коректувати свої ваги з'єднань [31].

У процесі навчання формується структура імовірнісної НМ. Розмірність  $N$  векторів навчальної вибірки визначає кількість нейронів і структуру вхідного шару імовірнісної НМ. Загальний розмір  $L$  навчальної вибірки відповідає загальній кількості нейронів шару зразків.

Представлення мережі кожного з  $L$  зразків супроводжується зазначенням від вчителю номеру  $k$ -го класу, якому належить вхідний зразок. Послідовність представлення навчальних зразків може бути будь якою. Після представлення усіх  $L$  векторів навчальної вибірки, формується структура мережі, а також, визначаються параметри мережі у вигляді матриці. На цьому процес навчання імовірнісної НМ завершується і мережа готова до класифікації невідомих зразків [22].

У робочому режимі мережі подається вхідний образ  $X$  невідомого класу, який спочатку нормалізується, а потім помножується на матрицю синаптичних вагів і, відповідним чином активує нейрони шару зразків. Кожний нейрон шару зразків показує на своєму виході деякий рівень активності усіх нейронів шару зразків свого  $k$ -го класу і показує на своєму виході загальний рівень активності даного класу. Далі відбувається визначення, який нейрон шару конкуренції має максимальний вихідний сигнал. Таким чином, по номеру  $k$ -го нейрону визначається номер класу  $k$ , до якого з найбільшою імовірністю, належить образ  $X$ .

Імовірнісні НМ належить до класу НМ з вчителем, який автоматично ставить ще одну важливу задачу - формування ефективної навчальної вибірки

[22].

Імовірнісні мережі виділяються високою швидкістю навчання. Порівняно з іншими НМ, це робить доцільним використовувати їх у задачах обробки сигналів акселерометру та класифікування людської діяльності, у режимі реального часу. Також, перевагою є можливість отримувати непогану точність результатів на відносно маленьких навчальних вибірках, навіть при наявності помилкових даних та шумів. Імовірнісні НМ ефективно використовуються для класифікації при дослідженні різних об'єктів та явищ, а точність напряму залежить від підготовки вхідних даних: забезпечення їх статистичної незалежності та нормалізації.

### **2.3. Метод логістичної регресії**

Метод логістичної регресії – це статистичний метод, що полягає у встановленні імовірності залежності безперервних вихідних від вхідних змінних [29].

На відміну від лінійної регресії, в методі логістичної регресії не відбувається прогнозування значення числової змінної, виходячи з вибірки вихідних значень. Замість цього, значенням функції є вірогідність того, що вихідне значення належить до певного класу. Основна ідея логістичної регресії полягає в тому, що простір вихідних значень може бути розділено лінійною границею на дві, відповідні класам, області [29]. Ця границя задається залежно від вихідних даних та алгоритму навчання. Логістична регресія у розрахунках користується методом максимальної правдоподібності. Цей метод є досить ефективним засобом вирішення задач оцінки параметрів випадкового процесу за даними спостереження при відомому вигляді законів розподілення відповідних випадкових вибірок, що залежать від параметрів, що оцінюються [30].

Види логістичної регресії:

1. Бінарна логістична регресія. Відповідь може бути представлена в одному з двох класів.

2. Мультиномінальна логістична регресія. Відповідь може бути представлена у вигляді трьох чи більше іменних класів.

3. Порядкова логістична регресія. Відповідь може бути представлена у вигляді трьох чи більше цифрових класів.

Логістична регресія потребує конкретних умов до даних, що використовуються для навчання. До таких умов відносять [30] :

- Незалежність. Кожен випробуваний не повинен залежити від інших.
- Лінійність. Між незалежною змінною та логітом залежної змінної повинна бути лінійна залежність.
- Відсутність мультиколінеарності. Незалежні змінні не повинні бути зв'язані між собою.
- Немає повного розподілу. Значення однієї змінної неможливо точно спрогнозувати по значенню іншої.

#### **2.4. Опис автономної системи розпізнавання та створення навчальної вибірки даних**

У наукових статтях [29-31] описані сучасні актуальні причини створення зручної автономної системи розпізнавання та класифікації життєвої діяльності людини. Також, вказані процеси створення системи та отримання з неї даних з 15 різних людей.

Для того, щоб отримати якісний, позбавлений зайвих шумів набір даних, випробуваний повинен почувати себе максимально комфортно, та відтворювати рухи так, як він робив би це у реальному житті [31].

У роботах пропонується варіант системи, а також програмне забезпечення до неї, що забезпечує високі результати з розпізнавання та класифікації фізичної активності людини у повсякденному житті. Функціонал та збір даних для дослідження може виконуватися у режимі реального часу. Система носіння для збору експериментальних даних легка у використанні та не потребує спеціального навчання. Запуск початку фіксування

акселерометрами прискорень, що виникають, у процесі виконання фізичних вправ відбувається по натисканню однієї кнопки. Завершується натисканням цієї ж кнопки. Види активності, що було запропоновані для фіксування [31]:

- робота за комп'ютером;
- приймання положення стоячи;
- стояння на місці;
- хода;
- розмова під час ходи;
- хода по сходам вгору\вниз;
- розмова під час стояння на місці.

Розроблена портативна система *BeaStream-v0.1* (рис. 2.2) [30] для носіння була спеціальна створена для отримання експериментальних мульти-сенсорних даних. Ядром системи є *BeagleBoard*, простий комп'ютер, що не потребує багато енергії для живлення, з встановленою на ньому оперативною системою *Linux*. Вона збирає аудіо та відео інформацію за допомогою веб-камери, а дані про переміщення піддослідного за допомогою акселерометра, передаючи інформацію для подальшої обробки шляхом *Bluetooth* з'єднання.



Рис. 2.2 Система *BeaStream-v0.1*

Уся система може легко переноситися однією рукою, а сенсори можуть розташовуватися поряд один з одним, або на різних частинах тіла, виходячи з особливостей експерименту. В цьому дослідженні система кріпилась за допомогою ремню на карабінах навколо грудної клітини. Акселерометр системи вимірює три значення прискорення по трьом вісям виміру  $x$ ,  $y$ ,  $z$  (рис. 2.3), вони записувалися до вибірки даних, що має вигляд файлу програмного пакету *Microsoft Office Microsoft Excel* (рис 2.4).

Файл містить більше 16 000 комірок із значеннями прискорень по 3 вісям чутливості акселерометру.

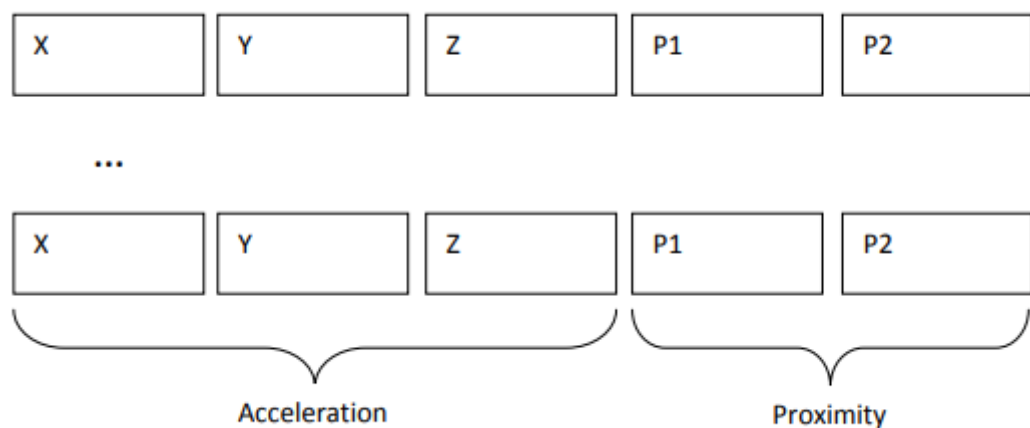


Рис. 2.3 Схема запису даних акселерометрів до навчальної вибірки

	1	2	3
1	0,1502,2215,2153,1		
2	1,1667,2072,2047,1		
3	2,1611,1957,1906,1		
4	3,1601,1939,1831,1		
5	4,1643,1965,1879,1		
6	5,1604,1959,1921,1		
7	6,1640,1829,1940,1		
8	7,1607,1910,1910,1		
9	8,1546,2045,1910,1		
10	9,1529,2049,1972,1		
11	10,1637,1978,1945,1		
12	11,1596,2046,1866,1		
13	12,1590,2006,1978,1		
14	13,1601,1966,1957,1		
15	14,1542,2003,1959,1		
16	15,1598,2027,1941,1		
17	16,1511,2258,1983,1		
18	17,1555,1980,2023,1		
19	18,1508,2468,1934,1		

Рис. 2.4. Вигляд Excel файлу з даними акселерометру

Навчальна вибірка була отримана з 15 піддослідних, 7 чоловіків та 8 жінок, віком в межах 27-35 років. Зручний форм-фактор *BeaStreammer-v0.1* надає можливість піддослідним проводити заміри в умовах, максимально зручних для них самих. Початок фіксації вихідних сигналів здійснюється при натисканні на кнопку, й завершуються по натисканню на цю ж кнопку. Вибір певної активності не відбувається, але піддослідних просили проводити виміри фізичних активностей у визначеному порядку. На кожний тип активності потрібно було виділяти не менше 5 хвилин. Загалом 15 піддослідних записували дані протягом 7 годин 13 хвилин, з наступним розподіленням [31]:

- хода по східцям: 60 хвилин;
- звичайна хода по рівній поверхні: 103 хвилини;
- робота за комп'ютером: 120 хвилин;
- стояння на місці: 54 хвилини;
- ведення розмови: 90 хвилин.



Дані з акселерометрів (рис.2.5) системи можна отримувати не тільки у лабораторних умовах, а й в інших неконтрольованих середовищах, що дозволяє максимально наблизити експеримент до реальних, повсякденних умов. П'ять повсякденних типів діяльності людини, таких як: хода, хода по сходам, стояння на місці, ведення розмови та робота за комп'ютером розглядаються як основні види фізичної активності і використовуються для тестування системи, щоб показати її ефективність та можливість класифікації дій з високою точністю до 93 відсотків.

На рис. 2.5. показані графіки сигналів акселерометру, порядковий номер – вид активності:

- 1 - хода;
- 2 - хода по сходам;
- 3 - ведення розмови;
- 4 - стояння на місці;
- 5 - робота за комп'ютером;




Рис. 2.5. Вихідні сигнали акселерометру при різних типах активностей

## **2.5. Застосування системи класифікації фізичної активності у цілях підвищення безпеки інформаційних систем**

Відомо, що хода людей унікальна. Дослідження підтверджують, що кожна людина має свій власний паттерн ходи. Дані, що були отримані з акселерометрів, це демонструють. Обробка та класифікація цих вихідних даних акселерометрів, під час ходи, може застосуватися у цілях авторизації, верифікації та аутентифікації користувачів мобільних пристроїв.

Аутентифікація – це процедура перевірки користувача шляхом звірення даних, занесених у систему безпеки, з тими що вводяться при спробі отримання доступу до пристрою.

Хоча зараз технологія верифікації за ходою, використовуються не так широко, її грамотна реалізація може бути застосована для значного підвищення безпеки та захисту особистої інформації у багатьох мобільних пристроях [32].

Верифікація користувачів, зазвичай, вимірюється двома основними параметрами. *False Accept Rate (FAR)* – параметр характеризуючий імовірність того, що система безпеки “прийме за свого” незареєстрованого користувача. Цей параметр застосовується для визначення надійності біометричних систем безпеки. *False Rejection Rate (FRR)* – параметр, що відображає імовірність того, що людина може бути не розпізнана системою й отримати відмову у доступі. Тобто, перший параметр характеризує загалом здатність системи забезпечити безпеку та захист персональних даних, в той час як другий стосується зручності користування системою безпеки. Разом з такими біометричними чинниками авторизації, як відбиток пальців та розпізнавання користувача по лицю, аутентифікація за ходою підвищує значення обох параметрів. Числове значення підвищення якості фактору багатою мірою залежить від розташування сенсору, та якості його кріплення [32].

Використаємо отриманий набір даних для розпізнавання діяльності людини за допомогою ймовірнісної нейронної мережі та логістичної регресії

## **2.6. Огляд програми та комп'ютерна програма для дослідження**

Аналіз даних, як правило, не передбачає можливості розглянути всю цікаву сукупність об'єктів. Обробка та вивчення великих обсягів даних є дорогим процесом, який вимагає значних затрат часу, а також неминуче призводить до помилок, пов'язаних з людським фактором. Для більшості задач буває цілком достатньо розглянути деяку частину всієї сукупності — вибірку. Розмір вибірки при цьому залежить від різноманітності об'єктів, представлених в генеральній сукупності (англ. Population) — всій сукупності досліджуваних об'єктів. Таким чином вибірка (англ. Sample) — це частина генеральної сукупності, певним способом відібрана з метою дослідження і отримання висновків про властивості та характеристики генеральної сукупності. У вибірці повинні бути представлені різні комбінації і елементи генеральної сукупності [32].

При виборі архітектури мережі звичайно випробовується кілька конфігурацій з різною кількістю елементів. Одним з основних показників є розбиття навчальної множини на навчальну і тестову [32].

Дослідження проводяться у середовищі *Python 3.8*, з використанням *Anaconda* та *Jupyter Notebook*. Щоб запустити мережу імовірнісного типу в *Anaconda* була загружена бібліотека *NeuPy*, за допомогою команди *pip install neuPy*.

Лістинг програми:

```
import pandas as pd

import numpy as np

from sklearn import metrics

from sklearn.model_selection import train_test_split

asseler_names = ['sequential', 'x_acceleration', 'y_acceleration', 'z_acceleration',
'label']

asseler_df = pd.read_csv("data/1.csv", sep=',', names=asseler_names)
```

```
asseler_df.isnull().values.any()
```

```
asseler_df['label'] = asseler_df["label"].replace(0,7)
```

```
asseler_df
```

```
array = asseler_df.values
```

```
dataset = array[:, 1:4]
```

```
targets = array[:, 4]
```

Ймовірнісна нейронна мережа

```
from neupy import algorithms
```

```
from sklearn.linear_model import LogisticRegression
```

```
from pandas import DataFrame as df
```

```
results = {"proportion": ["5:95", "10:90", "15:85", "20:80",  
                          "25:75", "30:70", "35:65", "40:60",  
                          "45:55", "50:50", "55:45", "60:40",  
                          "65:35", "70:30", "75:25", "80:20",  
                          "85:15", "90:10", "95:5"], "PNN": [], "Logistic Regression": []}
```

```
for test_proportion in [(0.05, 0.95), (0.1, 0.9), (0.15, 0.85), (0.2, 0.8),  
                        (0.25, 0.75), (0.3, 0.7), (0.35, 0.65), (0.4, 0.6),  
                        (0.45, 0.55), (0.5, 0.5), (0.55, 0.45), (0.6, 0.4),  
                        (0.65, 0.35), (0.7, 0.3), (0.75, 0.25), (0.80, 0.20),
```

$(0.85, 0.15), (0.90, 0.10), (0.95, 0.5)]$ :

```

train_size = test_proportion[0] # taking training set

test_size = test_proportion[1] # taking test set

seed = 7 # Random number seeding for repeatability of the code

x_train, x_test, y_train, y_test = train_test_split(dataset, targets,
train_size=train_size, test_size=test_size,

random_state=seed) pnn = algorithms.PNN(std=10, verbose=True)

pnn.train(x_train, y_train)

y_predicted = pnn.predict(x_test)

model_score_pnn = metrics.accuracy_score(y_test, y_predicted)

```

Модель логістичної регресії

```

model = LogisticRegression()

model.fit(x_train, y_train)

y_predict = model.predict(x_test)

model_score_lr = model.score(x_test, y_test)

old_pnn= results.get("PNN")

old_pnn.append(model_score_pnn)

results.update({"PNN": old_pnn})

old_lr = results.get("Logistic Regression")

old_lr.append(model_score_lr)

```

```

results.update({"Logistic Regression": old_lr})

print(resultsp[])

results_df = df.from_dict(results)

results_df

```

Штучна нейронна мережа створена з використанням бібліотек *pandas* – для роботи з датафреймом, та *numpy* – для роботи з матрицями та масивами вхідних даних (рис. 2.6).

	sequential	x_acceleration	y_acceleration	z_acceleration	label
0	0.0	1502	2215	2153	1
1	1.0	1667	2072	2047	1
2	2.0	1611	1957	1906	1
3	3.0	1601	1939	1831	1
4	4.0	1643	1965	1879	1
...	...	...	...	...	...
162496	162500.0	1927	2388	2074	7
162497	162500.0	1930	2383	2074	7
162498	162500.0	1929	2385	2076	7
162499	162500.0	1926	2385	2078	7
162500	162500.0	1922	2387	2078	7

Рис. 2.6. Вигляд вхідних даних для навчання мереж

## 2.7. Визначення типу активності людини за допомогою моделі ймовірнісної НМ

Було проведено дослідження впливу об'єму навчальних даних на точність визначення активності та отримано наступні результати. У таблиці 2.1 наведено вплив розбивки навчальної дати на точність визначення типу фізичної активності. У таблиці 2.2 наведено час затрачений на навчання мережі, залежно від розбивки навчальної вибірки.

Таблиця 2.1. Вплив розбивки дати на точність визначення активності

Відношення даних для навчання та тестування, %	Точність визначення типу роботи Імовірнісної НМ
45/55	0.6937544
50/50	0.6953760
55/45	0.6964554
60/40	0.6966508
65/35	0.6969194
70/30	0.6952315
75/25	0.6959826
80/20	0.6964093
85/15	0.6980637
90/10	0.6960187

Таблиця 2.2. Час затрачений на навчання залежно від розбивки вибірки

Відношення даних для навчання та тестування, %	Час, затрачений на навчання імовірнісної НМ
45/55	7 хвилин 13 секунд
50/50	7 хвилин 48 секунд
55/45	8 хвилин 9 секунд
60/40	8 хвилин 56 секунд
65/35	9 хвилин 23 секунди
70/50	10 хвилин 3 секунди
75/25	11 хвилин 7 секунд
80/20	12 хвилин 23 секунди
85/15	13 хвилин 45 секунд
90/10	15 хвилин 4 секунди

Дані, з таблиць 2.1 та 2.2 графічно відтворено в якості гістограм на рис. 2.7 та 2.8 відповідно.



Рис. 2.7. Гістограма, створена за таблицею 2.1





Рис. 2.8. Гістограма, створена за таблицею 2.2, час вказаний в секундах

Поділення навчальної вибірки на дані, що пійдуть для навчання мережі та тестування є важливим фактором, що впливає на подальшу ефективність роботи НМ. Найкращу точність імовірнісна мережа показала при розбитті у відношенні 85/15 відсотків.

Час, затрачений на навчання мережі, збільшується при збільшенні об'єму даних, поданих на навчання мережі, що є правдоподібним, так як програмі необхідно обробити більший об'єм даних.

## 2.8. Визначення типу активності людини за допомогою моделі логістичної регресії

Було проведено дослідження впливу об'єму навчальних даних на точність визначення активності та отримано наступні результати. Отримані дані наведено у таблицях 2.3 та 2.4, та графічно відображено на рис. 2.9 та 2.10 відповідно. У таблиці 2.3 вказано залежність точності визначення типу фізичної активності від розбивки навчальної вибірки для ймовірнісної НМ. У таблиці 2.4 наведено залежність часу, необхідного для навчання моделі логістичної регресії, залежно від розбивки даних.

Таблиця 2.3. Залежність точності визначення типу фізичної активності від розбивки навчальної вибірки

Відношення даних для навчання та тестування, %	Точність визначення типу роботи логістичної НМ
45/55	0.7165346
50/50	0.7143542
55/45	0.7194294
60/40	0.7190350
65/35	0.7149940
70/30	0.7182827
75/25	0.7156254
80/20	0.7205316
85/15	0.7198063
90/10	0.7232785

Таблиця 2.4. Залежність часу, необхідного для навчання моделі логістичної регресії

Відношення даних для навчання та тестування, %	Час, затрачений для навчання логістичної НМ
45/55	3 хвилини 15 секунд
50/50	3 хвилини 50 секунд
55/35	4 хвилини 12 секунд
60/40	5 хвилин 2 секунди
65/35	5 хвилин 48 секунд
70/30	6 хвилин 23 секунди
75/25	7 хвилин 33 секунди
80/20	8 хвилини 15 секунд
85/15	9 хвилин 11 секунд

90/10	10 хвилин 2 секунди
-------	---------------------

Аналізуючи точність визначення типу фізичної активності, можна сказати, що точність визначення типу фізичної активності та швидкості навчання при використанні логістичної регресії вище ніж у ймовірнісної НМ. Крім того, точність розпізнавання виду діяльності за допомогою логістичної регресії не так залежить від розбивки навчальної вибірки, як від самої якості нормалізації та відсутності шумів.



Рис. 2.9. Гістограма, створена за таблицею 2.3



Рис. 2.10. Гістограма, створена за таблицею 2.4, час вказаний у секундах

Кращий результат точності визначення типу фізичної активності логістична регресія демонструє при відношенні 90/10 розбиття даних на тестові та навчальні.

## 2.9. Визначення точності розпізнавання для різних даних фізичної активності

Оскільки, кожен з 15 файлів даних були створені різними людьми, при різних умовах, тому кожна з них має свою унікальну особливість. Крім того, кожен піддослідний відтворював фізичну активність у різних умовах.

Оскільки при перевірці впливу розбивки дати на ймовірнісну нейронну мережу, було визначено, що відношення 85/15 % видає найкращу точність.

Розглянемо задачу визначення точності розпізнавання типу фізичної активності для 15 наборів даних. Результати дослідження наведено в таблиці 2.5 та графічно відображено на рис. 2.11.

Таблиця 2.5 Точність визначення фізичної активності за допомогою ймовірнісної НМ

Номер файлу навчальної вибірки	Точність визначення виду фізичної активності
1	0,6980637
2	0,6759654
3	0,6856413
4	0,7045623
5	0,6987534
6	0,7158643
7	0,7345987
8	0,7456864
9	0,7256896
10	0,7463582
11	0,6978531
12	0,6874539
13	0,7045623
14	0,7148567
15	0,6832156

Найкращу точність отримано з навчальної вибірки файлу номер 10. Найгірший – 15. Аналізуючи отримані результати можна переконатися, що на точність визначення значною мірою впливає якість навчальної вибірки. Різниця між найгіршим та найкращим показником точності складає 0,0631426.

Логістична регресія під час попереднього дослідження показала найкращу точність при розбивці навчальної вибірки у пропорції 90/10, тому наступні дослідження будь проводитися з тим же розподіленням. Результати дослідження наведено в таблиці 2.6 та графічно відображено на рис. 2.12.

Таблиця 2.6. Точність визначення типу фізичної активності за допомогою логістичної регресії

Номер файлу навчальної вибірки	Точність визначення виду фізичної активності
1	0.7232785
2	0,7345682
3	0,7145683
4	0,7098456
5	0,7458941
6	0,7045793
7	0,7564123
8	0,7265896
9	0,7123654
10	0,7656452
11	0,7456532
12	0,7565642
13	0,7265486
14	0,7496543
15	0,7165432

Логістична регресія показує найвищу точність для вибірки номер 10.  
Різниця між найкращим та найгіршим результатом складає 0.0610659.



Рис. 2.11. Гістограма, побудована за даними таблиці 2.5



Рис. 2.12. Гістограма, побудована за даними таблиці 2.6

## 2.10. Перевірка ефективності розпізнавання навчених моделей

Після визначення найкращої навчальної вибірки для ймовірнісної НМ та логістичної регресії, важливо знати як вони функціонують на різних даних.

Після навчання за одним дата сетом потрібно перевірити ефективність вже навчених моделей для розпізнавання видів фізичної активності інших вибірок. Так як найкращу точність було отримано на даних 10, навчання було проведено на ній у процентному відношенні навчальних/тестових даних 85/15 та 90/10 для імовірнісної та логістичної мереж відповідно. Було проведено розпізнавання для 5 різних вибірок даних. Результати досліджень наведені у таблицях 2.7 та 2.8, а також графічно відтворені на рис. 2.13 та 2.14.

Таблиця 2.7. Визначення типу активності навченою імовірнісною НМ

Номер датасету для розпізнавання	Точність визначення типу фізичної активності
1	0,137683
2	0,197865
3	0,178964
4	0,215869
5	0,198719

Таблиця 2.8. Визначення типу активності навченою логістичною регресією

Номер датасету для розпізнавання	Точність визначення типу фізичної активності
1	0,178364
2	0,235974
3	0,215687
4	0,112365
5	0,156987






Рис. 2.13. Гістограма, побудована за даними таблиці 2.7




Рис. 2.14. Гістограма, побудована за даними таблиці 2.8

## 2.11. Висновки до розділу

У розділі були розглянуто ймовірнісна НМ та модель логістичної регресії, як інструмент для розпізнавання типу фізичної активності. Описано систему *BeaStream* – *v0.1*, що була використана для створення навчальної вибірки, яка

складається з вихідних даних акселерометру, вбудованого у систему.

Відповідно до проведених досліджень були отримані наступні результати: найкраща точність розпізнавання типу фізичної активності була отримана для моделі логістичної регресії з розбиттям навчальної вибірки у відношенні 90/10 %, та становить 76,5%. Найкраща точність розпізнавання типу фізичної активності для ймовірнісної нейронної мережі була зафіксована при розбитті навчальної вибірки відношенням 85/15% та склала 74,6%. Найбільш вдалою вибіркою для навчання моделей виявилась вибірка 10.

Тестування на 5 інших масивах даних для навчених моделей показали достатньо низьку ефективність. Для ймовірнісної НМ показник точності визначення типу фізичної активності становить від 13,7 % до 21,6 %, а для логістичної регресії – від 11,2 % до 23,6 %.

Аналізуючи отримані показники точності, можна сказати, що така результативність є недостатньою для використання у реальних розробках. Проте, низькі показники цілком логічні й правдоподібні, так як, різні вибірки були створені різними людьми. З цього можна зробити висновок, що в задачі розпізнавання фізичної активності майже неможливо створити універсальну навчальну вибірку даних для НМ.

## ВИСНОВКИ

У роботі було описано, що розпізнавання типу фізичної активності – це актуальна задача з можливостями застосування у багатьох сферах. Для цього доцільно використовувати такий сенсор, як акселерометр.

Наведено основні теоретичні відомості про датчик виміру прискорення. Фізичний принцип дії та основні його характеристики. Розглянуто основні технології виготовлення акселерометрів, а саме: п'єзореzystивну, п'єзоелектричну та мікроелектромеханічну.

Проаналізовано актуальні сфери застосування акселерометрів, в якості датчиків для розпізнавання та класифікації повсякденної діяльності людини. Також було запропоновано можливі нові шляхи застосування датчиків у подібних цілях.

Описано основні класичні методи для обробки інформації, що можливі для класифікації вихідних даних акселерометрів. Під час їх аналізу та порівняння, було з'ясовано, що для задачі обробки вихідних сигналів акселерометру найдоцільніше використовувати штучні нейронні мережі.

Для дослідження було обрано два типи методів обробки вихідного сигналу акселерометру: ймовірнісна НМ та логістична регресія. Описано основний принцип їх дій та порівняно особливості структур.

Визначено основні вимоги до системи отримання даних для нейронної мережі. Розглянуто мультисенсорну систему *BeaStream* – v0.1, яка була використана для створення навчальної вибірки даних. Вона має вигляд 15 файлів (для кожного піддослідного свій файл) *Excel*, що містять 3 значення прискорення по трьом вісям чутливості. В процесі проведення експерименту піддослідні виконували 7 типів повсякденних активностей.

Результати дослідження показують, що нейронні мережі ефективний інструмент для визначення типу фізичної активності, максимальна виявлена точність визначення у 76.5% випадків була зафіксована для логістичної мережі, при розбитті навчальної вибірки у відношенні 90/10 %. Також у ході дослідження наглядно було показано як сильно якість навчальної вибірки впливає на точність. Різниця між найбільшим та найменшим показником точності, залежно від якості вибірки склала 6.3 %, що дуже суттєво. У ході аналізу точності розпізнавання типу фізичної активності, вже навченою нейронною мережею було отримано низький результат точності, з найкращим показником у всього 23% . Це свідчить про те, що для аналізу діяльності, за допомогою обробки вихідних даних акселерометра нейронною мережею, необхідно створювати навчальну вибірку даних індивідуально для кожної людини, внаслідок унікальності техніки рухів.

## СПИСОК ЛІТЕРАТУРИ

1. А.Ю.Кононюк Нейронні мережі і генетичні алгоритми – К: Корнійчук, 2008. -446 с.
2. Колесник Ю. І. Електронні Пристрої Вимірювання Та Узгодження Сигналів.
3. Автомобильные акселерометры. Часть 3. Классификация и анализ Базовых рабочих принципов\Сысоева Светлана\ Компоненты и технологии\ №2\2006
4. Безвесільна О.М. Науково-теоретичні дослідження нового п'єзоелектричного гравіметра автоматизованої авіаційної гравіметричної системи в екстремальних умовах з використанням нейронних мереж: монографія / О.М. Безвесільна, А.Г. Ткачук, Г.С. Тимчик. – Житомир : ЖДТУ, 2014. – 224 с
5. Piezoresistive force rebalance accelerometer. United States Patent 5,596,144. Опубл. 21.01.1997 (Delco Electronics Corporation).
6. Автоматизація проектування МЕМС з використанням системи COMSOL : навч. посіб. [для студентів, аспірантів та науковців, які спеціалізуються в галузі автоматиз. проектування та мат. моделювання мікроелектромех. систем] / В. М. Теслюк, Р. З. Кривий, М. Р. Мельник ; М-во освіти і науки України, Нац. ун-т "Львів. політехніка". – Львів : Вид-во Львівської політехніки, 2016. – 216 с
7. Шуляк М. В. Методичне забезпечення до дисципліни "Мікроелектромеханічні прилади та системи". [Дипломна робота на отримання ступеня «бакалавр»]. – К.: "КПИ імені Ігоря Сікорського", 2019.
8. АВИ СОЛЮШНС. Особенности и сравнительные характеристики технологий изготовления твердотельных акселерометров [Електронний ресурс :] <https://avi-solutions.com/library/statyi/osobennosti/>

9. Олійник П. Б. Розробка бездротового датчика вібрації на основі MEMS акселерометра.
10. Коновалов С.Ф. Гироскопические системы./ Коновалов С.Ф., Никитин Е.А., Селиванова Л.М. Под ред. Д.С. Пельпора. Учебное пособие для вузов. — М.:Высш.школа, 1980.
11. Сысоева Светлана. Ключевые сегменты рынка MEMS-компонентов.
12. Горбунов А.В. Дифференциальная диагностика двигательной активности человека во время сна на основе пульсоксиметрии и акселерометрии / Горбунов А.В., Потлов А.Ю., Ахтямов А.Д., Трубиенко А.А./ Вестник Тамбовского университета. Серия Естественные и технические науки. Тамбов, 2013. Т. 18. Вып. 4. С. 1292-1294.
13. Зенкевич О. И. Метод конечных элементов в теории сооружений и в механике сплошных сред. — М.: Недра, 1974. — 240 с.
14. Периферійні Пристрої та ЕМС. Розділ 5 Пристрої передачі даних. [Електронний ресурс :] <http://pps.vtc.vn.ua/-5>
15. Поспелова И. Н. Учебно-методический комплекс дисциплины “Статистика” — часть 2.
16. Чабан Л. Н. Методы и алгоритмы распознавания образов в автоматизированном дешифрировании данных дистанционного зондирования.
17. Загоруйко Н. Г. Прикладные методы анализа данных и знаний. — Новосибирск: ИМ СО РАН, 1999.
18. Шуметов В. Г. Кластерный анализ: подход с применением ЭВМ. — Орел: ОрелГТУ, 2000. — 118 с.
19. Саймон Хайкин. Нейронные Сети. Полный курс. Второе издание.

20. Пахомова В. М. Рішення задачі маршрутизації в комп'ютерній мережі Придніпровської залізниці в основі нейронної моделі Хопфілда.
21. Интернет ресурс Neurohive. Нейросеть от MIT распознает, что происходит на видео, с точностью 95%. [Электронный ресурс :]  
<https://neurohive.io/ru/novosti/nejroset-rasposznayot-deystviya/>
22. Интернет ресурс Neuronus.com. Основные недостатки использования искусственных нейронных сетей и пути их решения. [Электронный ресурс :]  
<https://neuronus.com/theory/nn/240-osnovnye-nedostatki-ispolzovaniya-iskusstvennykh-nejronnykh-setej-i-puti-ikh-resheniya.html>
23. Р. Н. Кветный, Вероятностные нейронные сети в задачах идентификации временных рядов/ Р. Н. Кветный, В. В. Кабачий, О. О. Чумаченко.
24. Заенцев И.В. Нейронные сети: основные модели: Учебное пособие к курсу «Нейронные сети». – Воронеж, 1999. – 24 с.
25. Круглов В. В. Искусственные нейронные сети. Теория и практика. – М.:Горячая линия – Телеком, 2001. – 382 с.
26. Круглов В.В. Нечеткая логика и искусственные нейронные сети.– М.: Физматлит, 2001. – 224 с.
27. Как легко понять логистическую регрессию [Электронный ресурс] :  
<https://habr.com/ru/company/io/blog/265007/>
28. Студенческий научный журнал выпуск №15(59) [Электронный ресурс] :  
<https://sibac.info/journal/student/59/137750>
29. Casale, P. Pujol, O. and Radeva, P. "BeaStreamer-v0.1: a new platform for Multi-Sensors Data Acquisition in Wearable Computing Applications"
30. Casale, P. Pujol, O. and Radeva, P. "Human activity recognition from accelerometer data using a wearable device"

31. Casale, P. Pujol, O. and Radeva, P. "Personalization and user verification in wearable systems using biometric walking patterns"
32. Марченко О.О Актуальні проблеми Data Mining: Навчальний посібник для студентів факультету комп'ютерних наук та кібернетики./ О. Марченко, Т.Россада — Київ. — 2017. — 150 с.